一种多结构及文本融合的网络表征方法

李佳艺[1] 赵 宇[1] 王 莉[2]
(太原理工大学信息与计算机学院 山西 晋中 030600)[1] (太原理工大学大数据学院 山西 晋中 030600)[2]

摘 要 网络表征通过对网络结构的深度学习得到节点的矢量表征,挖掘网络中潜在的信息,是社会计算中的一种重要降维方法。针对一种融合了网络中的文本和结构的、基于矩阵分解的网络表征方法TADW,首先分析并讨论了文本属性矩阵在矩阵分解式中的位置对网络表征效果的影响,并对此方法进行了优化;在此基础上,提出了一种融合关系结构、交互结构和文本属性的社交网络表征方法。在多个数据集上的实验结果表明,该方法在多分类任务中优于其他经典网络表征方法。

关键词 社交网络,表征学习,多网络结构,矩阵分解

中图法分类号 TP181 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2018.07.006

Network Representation Model Based on Multi-architectures and Text Fusion

LI Jia-yi[1] ZHAO Yu[1] WANG Li[2]
(College of Information and Computer,Taiyuan University of Technology,Jinzhong,Shanxi 030600,China)[1]
(College of Data Science,Taiyuan University of Technology,Jinzhong,Shanxi 030600,China)[2]

Abstract Network representation obtains the vector representations of nodes by deeply learning network structure,and mines the potential information on the network,which is an important method of reducing dimension in social computing. As for TADW,which is a network representation method based on matrix decomposition and combining text and structure,this paper first analyzed and discussed the influence of the location of text attributes matrix on network representation. Then,it proposed a social network representation method that incorporates relationship structure,interaction structure and textual attributes. Experimental results on multiple datasets show that the proposed method outperforms other classical network representation methods in classification tasks.

Keywords Social network,Representation learning,Multi-network structures,Matrix factorization

1 引言

互联网使整个世界联系在一起,同时也促使社交网络进入一个新阶段。人在不同社交应用中的社交目的多种多样,人的社交行为涵盖了关系、内容、互动3个部分,从而构成了复杂的社交网络。通过计算分析并挖掘社交网络中的潜在信息,可在一定程度上提升商品推荐、关系预测、信息传播、群体事件发现、态势预测等任务的质量。

当前社交网络分析的方法主要是基于图模型的,可分为图模型匹配方法、指数图模型方法、基于概率的方法[1-3]等。

深度学习以及word2vec[4]方法的提出为网络计算提供了新的思路,这类策略利用已知的网络结构进行网络表征,不仅能够挖掘和表征出网络的潜在信息,还能降低网络表征的维度[5-6],大大减小了计算的复杂度,同时也能被用于经典的数据挖掘算法中来解决问题。

2008年以来,多种网络表征方法相继被提出。Mei等[7]提出了利用网络文本属性来学习网络表征的NetPLSA方法。之后出现了多种利用网络中的结构来学习网络表征的方法,如DeepWalk,LINE,Node2Vec[8-10]等。其中,DeepWalk方法利用网络结构的均匀随机游走策略得到随机游走序列,随后引入Skip-Gram[4]对得到的序列进行表征学习,从而得到网络的表征。利用结构信息进行网络表征的方法取得了重大的突破,但这些方法有着固定的框架,很难把网络中的其他属性添加进去。因此,在网络很复杂的情况下,典型的网络表征很难充分利用网络中的信息,不能达到最理想的效果。

在以微博、QQ、微信等平台为代表的社交网络中,用户之间相互关注、加好友等行为构成了关系结构;转发帖子、评论、收藏、点赞、点踩、私信等交互行为构成了用户交互结构;不同行为信息构成了复杂的网络结构。在社交网络中,不仅有复杂的网络结构,还有丰富的文本信息,每个用户拥有自己相对

到稿日期:2017-07-22 返修日期:2017-09-28 本文受国家高技术研究发展计划863项目(2014AA015204),山西自然科学基金项目(201703D421013),中科院计算技术研究所网络数据科学重点实验室课题(CASNDST20140X)资助。

李佳艺(1995-),女,硕士生,主要研究方向为社交网络、大数据挖掘,E-mail:1057339032@qq.com;**赵 宇**(1992-),女,硕士生,主要研究方向为社交网络、大数据挖掘,E-mail:411975417@qq.com;**王 莉**(1971-),女,博士,教授,CCF会员,主要研究方向为人工智能、大数据挖掘、社交网络,E-mail:462672475@qq.com(通信作者)。

稳定的属性，比如昵称、性别、生日、职业、血型、星座、所在地区等；还有在各种行为中产生的文本内容，如在微博上用户根据自己的兴趣爱好发表的博客、转发的帖子、对其他用户帖子的评论等。

虽然目前已有一些结合网络中文本和结构信息进行网络表征的方法，但是针对社交网络中复杂的结构信息和丰富的文本信息，在网络表征的算法中融合何种属性以及如何融合这些属性，仍是未解决的问题。

2　相关研究

在很多网络中文本信息和网络结构是共存的，一些学者开始关注多种信息融合的网络表征。其中有使用神经网络的方法，其典型代表有 Tu 等[11]提出的 CANE 算法，该方法通过加入邻居节点的信息来学习网络中文本的表征，用 CNN 对文本信息进行编码，并引入相互注意力机制，节点邻居不同，学习到的网络表征就不同；Pan 等[12]提出了 TriDNR 算法，该方法利用耦合神经网络体系结构，综合节点结构、节点内容和节点标签（如果可用）来学习最优的节点表示。还有一些学者使用了矩阵建模的方法，把网络结构和文本信息用矩阵统一起来进行网络表征，相关研究有 Huang 等[13]提出的 LANE 算法，该方法将标签信息整合到网络表征中，学习到的网络表征保留了原始网络的拓扑结构和节点属性的相似度；Yang 等[14]结合网络的结构和文本属性，基于矩阵分解提出了 TADW（Text-Associated Deep Walk）方法来学习网络表征。上述方法使用了节点标签信息、节点文本信息、单结构信息，但没有利用多结构信息，而在真实的网络中不仅存在丰富的外部信息，还存在多种网络结构，而多结构中也包含着很多潜在信息。

考虑到网络的多结构性，我们希望网络的表征在考虑外部信息的同时可以结合多种结构信息。经过分析并对比上述算法后发现，TADW 方法对网络表征中多结构和文本信息的融合有一定的启发作用。

TADW 方法在关系矩阵分解时加入了文本特征，既考虑了结构，也结合了文本，但针对矩阵分解的特殊性，文献[14]中并没有对 TADW 方法中文本的融合是否最优进行讨论和分析。因此，本文基于 TADW 方法的原理，通过大量实验论证，提出了一种改进的融合文本属性的网络表征方法。同时，考虑到社交网络中多种结构信息和文本信息并存的情况，本文提出了一种融合多结构信息和丰富文本信息的网络表征方法，以提升网络表征效果。

本文第 3 节简单介绍 TADW 方法，并分析验证 TADW 中文本特征位置对网络表征的影响；第 4 节针对社交网络的特殊性，基于 TADW 方法提出一种多结构及文本融合的网络表征方法；第 5 节通过多分类任务的实验验证本文所提网络表征的有效性。

3　问题模型

3.1　网络模型

社交网络中，用户之间由关注、朋友、粉丝等自报道信息构成关系网络，通过相互转发消息、私信、评论、收藏、点赞、点踩等形成交互网络。两种网络结构既有联系又有区别：交互网络由 $G_{\text{trans}}=(V,E,T)$ 表示，其中 V 是交互网络顶点的集合，$v_i(v_i\in V)$ 表示用户，E 是边的集合，边 $e=(v_i,v_j)\in E$，v_i 和 v_j 表示发生交互的一对用户，T 是用户文本信息的集合；关系网络由 $G_r=(V',E')$ 表示，其中 V' 表示关系网络中用户的集合，$v_i'\in V'$，E' 表示存在关系的用户对的集合，$e'=(v_i',v_j')\in E'$，这里 $V=V'$，即不同网络结构中的用户是相同的。

3.2　TADW 简介

TADW 方法[14]由清华大学的刘知远团队所提，该方法是结合了网络结构和文本进行网络表征的典型方法。网络由 $G=(V,E,T)$ 表示，其中 V 是顶点集合，E 是网络的边集合，T 是所有顶点的文本特征。文献[14]证明了 DeepWalk 等价于矩阵分解 $M=W^{\mathrm{T}}H$，因此本文使用归纳矩阵分解[15]的方法进行矩阵分解，在矩阵分解的过程中加入文本特征来学习网络表征。

TADW 的模型如图 1 所示，其中 $M\in R^{|V|\times|V|}$，M_{ij} 表示 G 中顶点 v_i 随机游走到顶点 v_j 的平均概率的对数，根据 DeepWalk 原理得到。$W\in R^{k\times|V|}$，k 是顶点表征的维度，$|V|$ 是 G 中的顶点个数。$T\in R^{f_t\times|V|}$，T 中每一列对应一个顶点的文本特征表示，f_t 是每个顶点文本特征表示的维度。$H\in R^{k\times f_t}$，这里 $k\ll|V|$。TADW 方法中的顶点表征为 $[W^{\mathrm{T}}\otimes T^{\mathrm{T}}*H^{\mathrm{T}}]$（$\otimes$ 表示直接连接两个矩阵中的各个分量，上标 T 表示矩阵转置，$*$ 表示矩阵之间的乘积），最终网络中顶点的表征维度为 $2k$。

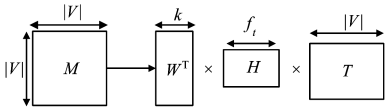

图 1　TADW 模型

Fig. 1　TADW model

归纳矩阵分解即最小化公式(1)，对矩阵 M 分解得到 W 和 H，使得 $M\approx X^{\mathrm{T}}W^{\mathrm{T}}HY$。在文献[15]中，$M$ 表示两种属性的关系的观察矩阵，X 表示一种属性的特征矩阵，Y 表示另一种属性的特征矩阵，学习到的 $W^{\mathrm{T}}H$ 是两种属性潜在的关系矩阵。

$$\min_{W,H}\sum_{(i,j)\in\Omega}(M_{ij}-(X^{\mathrm{T}}W^{\mathrm{T}}HY)_{ij})^2+\frac{\lambda}{2}(\|W\|_F^2+\|H\|_F^2) \tag{1}$$

从式(1)可知归纳矩阵分解需要两个特征，为了方便，分别称其为 X 特征和 Y 特征。TADW 方法中只用到了文本特征 T，文献[14]用单位矩阵 E 表示 X 特征，用文本特征矩阵 T 表示 Y 特征。由此，TADW 方法的优化目标变为式(2)，矩阵分解的结果为 $M\approx EW^{\mathrm{T}}HT$。

$$\min_{W,H}\sum_{(i,j)\in\Omega}(M_{ij}-(W^{\mathrm{T}}HT)_{ij})^2+\frac{\lambda}{2}(\|W\|_F^2+\|H\|_F^2) \tag{2}$$

3.3　文本特征位置对网络表征的影响

本文首先对融合文本和关系结构的不同网络表征方法的效果进行分析。根据式(1)和 TADW 方法的思想，在等价的矩阵分解模型中，文本特征 T 可以处于 X 或 Y 特征矩阵位置。根据文本特征位置的不同，本文主要分析了 4 种不同表征方法的质量。下面对 4 种网络表征方法进行详细介绍。

当文本特征 T 放置在 Y 特征位置时，网络表征方法分为 $[W^{\mathrm{T}}]$ 和 $[W^{\mathrm{T}}\otimes T^{\mathrm{T}} * H^{\mathrm{T}}]$ 两种。

1) W^{T}：文献[14]对矩阵分解和 DeepWalk 方法的等价性进行了证明，指出由 DeepWalk 方法得到的网络表征为 W^{T}。在矩阵分解模型中考虑文本特征时，可得到图 1 所示模型，其中 W^{T} 已包含若干文本特征或由文本特征带来的影响，可以作为表征学习的一种结果。

2) $[W^{\mathrm{T}}\otimes T^{\mathrm{T}} * H^{\mathrm{T}}]$：为 TADW 方法中的网络表征，即将矩阵分解得到的表征结果与文本特征 T 进行连接后作为最终表征。

当文本特征 T 放置在 X 特征位置时，网络表征方法分为 $[T^{\mathrm{T}} * W^{\mathrm{T}}]$ 和 $[T^{\mathrm{T}} * W^{\mathrm{T}}\otimes H]$ 两种。

1) $[T^{T} * W^{\mathrm{T}}]$：该表征考虑了文本信息，但没有考虑分解式中 H 隐含的信息。

2) $[T^{\mathrm{T}} * W^{\mathrm{T}}\otimes H]$：将文本特征 T 置于 X 特征位置时的网络表征形式。

下面对这 4 种不同表征的效果进行数值分析。

3.3.1 数据准备和实验设置

在 Cora，Citeseer，Wiki 3 个不同来源的数据集上进行实验，以分析在 TADW 模型的基础上所提到的 4 种不同网络表征方法的性能。这 3 个数据集中，Cora 和 Citeseer 描述了论文间的引用关系。其中，Cora 数据集包含 2708 篇关于机器学习的文章，分为 7 种类型，每篇论文可有多个主题词，共有 1433 个主题词，论文之间的引用关系有 5429 条；Citeseer 数据集包含 3312 篇文章，分为 6 种类型，包含 3703 个主题词，文章之间的引用关系有 4732 条；Wiki 数据集中有 2405 篇文档，19 种类型，包含 4973 个主题词，文档之间存在的联系共有 17981 条。

本实验使用的参数与 TADW 中的参数一样，$f_t=200$，顶点表示维度是 $2k$，正则化参数 $\lambda=0.2$，Cora 和 Citeseer 数据集中 $k=80$，Wiki 数据集中 $k=100$。

在实验数据的预处理中，通过对文档主题使用 TF-IDF 算法得到文本特征矩阵 T；同时，考虑到计算性能，使用 SVD 算法对特征矩阵进行降维处理。在后文的实验中，文本特征矩阵 T 均是经过上述处理得到的。

3.3.2 实验结果及分析

在这 3 个数据集上分别使用上述 4 种不同方法得到网络表征，并用这些表征完成多分类任务，最后用分类准确度评价文本位置对网络表征质量的影响。本实验在进行多分类任务时使用的分类器是基于有监督学习的 SVM[16] 分类器。若分类准确度高，则说明网络表征效果较好。

实验结果如表 1－表 3 所列，其中方法②就是 TADW 原始的表征方法。

表 1 Citeseer 数据集上的分类准确度

Table 1 Classification accuracy on Citeseer dataset

Method	Embedding	Train_radio				
		0.1	0.2	0.3	0.4	0.5
①	$[W^{\mathrm{T}}]$	0.6774	0.7089	0.7194	0.7244	0.7264
②	$[W^{\mathrm{T}}\otimes T^{\mathrm{T}} * H^{\mathrm{T}}]$	0.7016	0.7232	0.7311	0.7367	0.7366
③	$[T^{\mathrm{T}} * W^{\mathrm{T}}]$	0.6950	0.7169	0.7222	0.7276	0.7292
④	$[T^{\mathrm{T}} * W\otimes H]$	**0.7102**	**0.7328**	**0.7390**	**0.7441**	**0.7443**

表 2 Wiki 数据集上的分类准确度

Table 2 Classification accuracy on Wiki dataset

Method	Embedding	Train_radio						
		0.03	0.07	0.1	0.2	0.3	0.4	0.5
①	$[W^{T}]$	0.4251	0.5872	0.6251	0.6756	0.6903	0.7005	0.7089
②	$[W^{\mathrm{T}}\otimes T^{\mathrm{T}} * H^{\mathrm{T}}]$	0.5798	0.6857	0.7167	0.7599	0.7737	0.7830	0.7916
③	$[T^{\mathrm{T}} * W^{\mathrm{T}}]$	0.5822	0.6780	0.7115	0.7478	0.7599	0.7695	0.7776
④	$[T^{\mathrm{T}} * W\otimes H]$	**0.5902**	**0.6948**	**0.7334**	**0.7757**	**0.7941**	**0.8040**	**0.8096**

表 3 Cora 数据集上的分类准确度

Table 3 Classification accuracy on Cora dataset

Method	Embedding	Train_radio				
		0.1	0.2	0.3	0.4	0.5
①	$[W^{\mathrm{T}}]$	0.8113	0.8485	0.8592	0.8595	0.8633
②	$[W^{\mathrm{T}}\otimes T^{\mathrm{T}} * H^{\mathrm{T}}]$	**0.8218**	**0.8500**	**0.8613**	**0.8674**	**0.8696**
③	$[T^{\mathrm{T}} * W^{\mathrm{T}}]$	0.7290	0.7611	0.7703	0.7736	0.7736
④	$[T^{T} * W\otimes H]$	0.7852	0.8152	0.8244	0.8288	0.8332

表 1－表 3 列出了 3 个数据集上的分类准确度，其表现出来的共同特征为：连接 W^{T} 和文本特征的网络表征效果普遍高于没有连接文本特征的结果，即 $[W^{\mathrm{T}}\otimes T^{\mathrm{T}} * H^{\mathrm{T}}]$ 的表征效果优于 $[W^{\mathrm{T}}]$，$[T^{\mathrm{T}} * W^{\mathrm{T}}\otimes H]$ 的效果优于 $[T^{\mathrm{T}} * W^{\mathrm{T}}]$ 的效果。这说明文本特征矩阵 T 不仅在求取表征矩阵时有用，还有助于提升最终的网络表征效果，而且分解得到的 H 矩阵中也包含了网络中隐含的信息，因此文本特征矩阵 T 不可忽略。

在 3 个数据集上表现出的不同结果有：在 Cora 数据集上，文本特征 T 置于 Y 的位置时得到的网络表征效果优于其置于 X 的位置的网络表征效果。而在 Citeseer 和 Wiki 数据集上，文本特征 T 置于 X 的位置时得到的网络表征效果 $[T^{\mathrm{T}} * W^{\mathrm{T}}\otimes H]$ 优于其置于 Y 的位置时得到的网络表征效果。这个区别的产生与数据集中的文本表征矩阵 T 有一定关联。在 Citeseer 和 Wiki 数据集上的主题词数远远多于 Cora 数据集上的主题词数，由于 3 个数据集上的文本特征矩阵 T 是根据文档关键词和 TF-IDF 算法得到的，主题数越多，得到的文本特征矩阵就会越稀疏，虽然经过 SVD 算法降维得到的文本特征矩阵的维度相同，但是在主题词较少的情况下，文本的表征效果会更好。

这个规律可以反映出文本特征在分解式中的位置对网络表征的影响，同时有助于找到更合理的网络表征方法。即当网络顶点文本中所涉及的主题词较少时，$[W^{\mathrm{T}}\otimes T^{\mathrm{T}} * H^{\mathrm{T}}]$ 方法表征的效果会比较好；当主题词较多时，$[T^{\mathrm{T}} * W^{\mathrm{T}}\otimes H]$ 方法表征的效果会更好。

4 多结构及文本融合的网络表征

4.1 社交网络的多结构性

网络表征的一般模型中，都假设顶点间的关系是静态的，网络结构是单一的，而社交网络中多种结构关系并存，结构复杂，同时每个用户会产生丰富的文本信息，在用户节点表征中如果能够融合这些复杂的结构特征及文本属性信息，那么节点表征对用户的表示能力将会更强，而用户分析的结果则会更精准。

4.2　多结构及文本融合的网络表征模型

针对社交网络中交互结构和关系结构并存、属性文本和关系结构混杂的情况，基于 TADW 模型，本文进一步提出了一种多结构及文本融合的网络表征模型（Multi-structure, text-associated DeepWalk，MsTADW），如图 2 所示。其中，$M \in R^{|V| \times |V|}$，M_{ij} 表示交互网络 G_{trans} 的顶点 v_i 游走到顶点 v_j 的平均概率的对数；T 为文本特征矩阵，使用 TF-IDF 算法对用户文本内容计算得到，$T \in R^{f_t \times |V|}$，f_t 是用户文本特征表示的维度；$|V|$ 表示 G_{trans} 中顶点的个数；$W \in R^{k \times f_t}$，这里 $k \ll |V|$；$H \in R^{k \times f_r}$；R 表示关系网络的生成矩阵，由对关系网络 $G_r = (V', E')$ 进行随机游走得到，与 M 矩阵的生成算法相同。然后使用 SVD 降维，$R \in R^{f_r \times |V'|}$，$f_r$ 为关系网络中每个用户节点的表征维度。经过学习，最终的网络节点表征为 $[T^{\mathrm{T}} * W^{\mathrm{T}} \otimes R^{\mathrm{T}} * H^{\mathrm{T}}]$，维度为 $2k$。

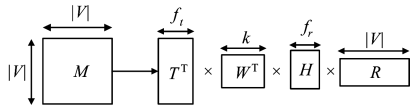

图 2　MsTADW 模型

Fig. 2　MsTADW model

MsTADW 模型中，网络表征学习的优化目标如式（3）所示。使用共轭梯度下降法迭代更新矩阵 W 和矩阵 H，使得 $M \approx T^{\mathrm{T}} W^{\mathrm{T}} HR$。

$$\min_{W,H} \sum_{(i,j) \in \Omega} (M_{ij} - (T^{\mathrm{T}} W^{\mathrm{T}} HR)_{ij})^2 + \frac{\lambda}{2} (\| W \|_F^2 \| H \|_F^2) \tag{3}$$

MsTADW 针对社交网络的特殊性，结合了网络中的多种信息进行网络节点表征。为验证该方法的有效性，在多个数据集上进行实验，并将其与传统的网络表征方法进行比较分析。

5　实验及结果分析

5.1　实验数据及参数设置

在实验数据集的选择和参数设置上，考虑到第 3 节实验中的 Cora，Wiki，Citeseer 3 个数据集上仅有一种结构信息，即论文引用关系，缺少多种结构信息，本次实验中没有继续使用这 3 个数据集，而使用了采自新浪微博的数据集 Microblog。该数据集采集了 2009 年 8 月 28 日到 2012 年 12 月 26 日新浪微博 1701 个用户的行为信息，包括用户之间互加好友的信息、相互转发微博和评论的记录，以及发表微博的内容、评论的内容等。其中，用户转发记录 90962 条，好友关系 29439 个，用户兴趣分为 10 类，主题词是对用户发表博客、转发博客、评论博客的内容进行分词、去停顿词、去重后得到的，共有 68362 个。

本实验中的交互结构由用户转发微博的行为构成，关系结构由用户互加好友、互相关注的行为构成，其中 $|V| = 1701$，$f_r = 200$，其余参数与 TADW 的参数一样，$f_t = 200$，$k = 100$，正则化参数 $\lambda = 0.2$，顶点的表征维度为 $2k$。

网络表征的效果仍然采用其在同一分类任务上的分类质量进行评估。实验中采用 SVM 分类器对用户兴趣分类的准确度来验证不同网络表征的效果，将在 Microblog 数据集上使用的训练集比率分别设定为 10%，20%，30%，40%，50%。

5.2　多结构及文本融合对网络表征效果的影响

为了验证本文提出的 MsTADW 模型的有效性，选取了 DeepWalk，TADW，RADW 作为基准比较对象。

DeepWalk 方法是一种基于交互结构的网络表征。根据式（1），DeepWalk 方法中的 X 特征和 Y 特征都是用单位矩阵 E 来表示的，网络表征为 $[W^{\mathrm{T}}]$。

TADW 方法是融合了交互结构和文本信息的网络表征方法，该方法按照矩阵分解时特征矩阵位置的不同有两种表征，分别为 $[W^{\mathrm{T}} \otimes T^{\mathrm{T}} * H^{\mathrm{T}}]$，$[T^{\mathrm{T}} * W^{\mathrm{T}} \otimes H]$，为了方便，将两种表征方法分别命名为 TADW1，TADW2。

RADW 是本文为了分析两种不同关系结构信息对网络表征的影响，在 TADW 模型中用关系结构特征 R 代替文本特征 T 得到的网络表征方法，其网络表征为 $[W^{\mathrm{T}} \otimes R^{\mathrm{T}} * H^{\mathrm{T}}]$。

第 3 节已验证了在 TADW 方法中文本特征在 X 特征位置和 Y 特征位置时学习到的网络表征的效果是不同的，这里在 Microblog 数据集上也对 $[W^{\mathrm{T}} \otimes T^{\mathrm{T}} * H^{\mathrm{T}}]$ 和 $[T^{\mathrm{T}} * W^{\mathrm{T}} \otimes H]$ 方法进行了对比实验。

最后，将 MsTADW 与 DeepWalk，RADW 和 TADW 方法进行对比实验，以验证多结构及文本融合的网络表征方法的有效性。实验结果如表 4 所列。

表 4　多结构对网络表征效果的影响

Table 4　Influence of Multi-structures on network representation

Method	Embedding	Train_radio				
		0.1	0.2	0.3	0.4	0.5
DeepWalk	$[W^{\mathrm{T}}]$	0.2348	0.2443	0.2473	0.2469	0.2515
RADW	$[W^{\mathrm{T}} \otimes R^{\mathrm{T}} * H^{\mathrm{T}}]$	0.4100	0.4518	0.4622	0.4640	0.4748
TADW1	$[W^{\mathrm{T}} \otimes T^{\mathrm{T}} * H^{\mathrm{T}}]$	0.3720	0.4350	0.4413	0.4371	0.4492
TADW2	$[T^{\mathrm{T}} * W^{\mathrm{T}} \otimes H]$	0.3904	0.4624	0.4734	0.4727	0.4959
MsTADW	$[T^{\mathrm{T}} * W^{\mathrm{T}} \otimes R^{\mathrm{T}} * H^{\mathrm{T}}]$	**0.4348**	**0.4666**	**0.4753**	**0.4862**	**0.4922**

表 4 的实验结果表明，在多种训练比率的情况下，RADW 用于分类的准确率比 DeepWalk 的准确率平均高出 20%左右，网络表征效果有了显著的提升。

TADW2 方法的 $[T^{\mathrm{T}} * W^{\mathrm{T}} \otimes H]$ 表征效果比 TADW1 方法的 $[W^{\mathrm{T}} \otimes T^{\mathrm{T}} * H^{\mathrm{T}}]$ 好，说明在 Microblog 数据集上当文本特征放在 X 特征的位置时，表征效果更好。在该数据集上的主题词有上万个，从而也说明了当主题词较多时，$[T^{\mathrm{T}} * W^{\mathrm{T}} \otimes H]$ 方法的表征效果会更好，同时验证了本文对文本特征位置对网络表征影响分析的正确性。

MsTADW 方法的准确率比 RADW 方法提高了 2%左右，MsTADW 方法比 TADW1 方法中表征为 $[W^{\mathrm{T}} \otimes T^{\mathrm{T}} * H^{\mathrm{T}}]$ 的准确率提高了 5%左右；而在训练比率较低的情况下，其准确度高于表征为 $[T^{\mathrm{T}} * W^{\mathrm{T}} \otimes H]$ 的方法。该结果说明了对于社交网络，文本特征和结构特征同等重要，在训练样本较少的情况下，网络中的各种信息更能相互补充，达到多信息有

（下转第 77 页）

on Information Acquisition. IEEE，2006：1062-1066.

[4] YAN C，GAO S，LUO H，et al. A hybrid algorithm based on tabu search and chemical reaction optimization for 0-1 Knapsack problem[C]// International Conference in Swarm Intelligence. Springer，Cham，2015：229-237.

[5] HAN K H，KIM J H. Quantum-inspired evolutionary algorithm for a class of combinatorial optimization[J]. IEEE Transactions on Evolutionary Computation，2002，6(6)：580-593.

[6] SHEN W，XU B，HUANG J P. An Improved Genetic Algorithm for 0-1 Knapsack Problems[C]// International Conference on NETWORKING & Distributed Computing. IEEE Computer Society，2011：32-35.

[7] TRUONG T K，LI K，XU Y. Chemical reaction optimization with greedy strategy for the 0-1 knapsack problem[J]. Applied Soft Computing Journal，2013，13(4)：1774-1780.

[8] EUSUFF M，LANSEY K，PASHA F. Shuffled frog-leaping algorithm：a memetic meta-heuristic for discrete optimization[J]. Engineering Optimization，2006，38(2)：129-154.

（上接第 41 页）

效融合的效果，进而提升网络的表征效果。

综合上述实验结果：在基于矩阵分解的网络表征中，使用多种网络结构比使用单一网络结构学习到的网络表征能取得更好的效果，同时也证明了本文提出的融合了多种结构和文本信息的网络表征方法 MsTADW 有一定的优越性，尤其在有标注数据较少的情况下，该方法有更大的优势。

结束语　本文从两个方面对 TADW 方法进行了改进和深入分析。首先，通过大量实验结果证明了文本特征在分解式中的位置会影响网络表征的效果，如果网络中顶点的主题词数比较少，那么根据归纳矩阵分解的原理，文本特征 T 放在分解式中 Y 特征的位置时学习到的网络表征更高效。另外，针对社交网络的特殊性，提出了一种多结构及文本融合的网络表征方法 MsTADW，经与 DeepWalk 方法及 TADW 方法在分类任务性能上的对比可知，MsTADW 方法学习到的网络表征在进行多分类时准确率有了一定的提高；同时，MsTADW 方法在训练数据较少的情况下能取得更好的效果。进一步，我们可将本文方法扩展应用到其他具有多种结构的网络中，也将对其他应用场景中不同任务目标情况下的网络表征的学习方法进行更深入的研究。

参 考 文 献

[1] COYAL A，BONCHI F，LAKSHMANAN L. Learning influence probabilities in social networks[C]// ACM International Conference on Web Search & Data Mining. ACM，2010：241-250.

[2] CRANMER S，DESMARAIS B. Inferential Network Analysis with Exponential Random Graph Models[J]. Political Analysis，2011，19(1)：66-86.

[3] FAN W. Graph pattern matching revised for social network analysis[C]// International Conference on Database Theory. ACM，2012：8-21.

[4] MIKOLOV T，SUTSKEVER I，CHEN K，et al. Distributed Representations of Words and Phrases and their Compositiona-lity [J]. Advances in Neural Information Processing Systems，2013，26：3111-3119.

[5] KUANG L W，HAO F，YANG L，et al. A Tensor-Based Approach for Big Data Representation and Dimensionality Reduction[J]. IEEE Transactions on Emerging Topics in Computing，2017，2(3)：280-291.

[6] CUNNINGHAM J，YU B. Dimensionality reduction for large-scale neural recordings[J]. Nature Neuroscience，2014，17(11)：1500-1509.

[7] MEI Q Z，CAI D，ZHANG D，et al. Topic modeling with network regularizations[C]// Proceedings of the 17th International Conference on World Wide Web. 2008：101-110.

[8] PEROZZI B，AL-RFOU' R，SKIENA S. DeepWalk：online learning of social representations[C]// Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2014：701-710.

[9] TANG J，QU M，WANG M，et al. LINE：Large-scale Information Network Embedding[C]// Proceedings of the 24th International Conference on World Wide Web. 2015：1067-1077.

[10] GROVER A，LESKOVEC J. node2vec：Scalable Feature Learning for Networks[C]// Proceedings of International Conference on Knowledge Discovery & Data Mining(KDD). 2016：855-864.

[11] TU C C，LIU H，LIU Z Y，et al. CANE：Context-Aware Network Embedding for Relation Modeling[C]// Meeting of the Association for Computational Linguistics. 2017：1722-1731.

[12] PAN S R，WU J，ZHU X Q，et al. Tri-Party Deep Network Representation[C]// Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence. 2016：1895-1901.

[13] HUANG X，LI J D，HU X. Label Informed Attributed Network Embedding[C]// Proceedings of the Tenth ACM International Conference on Web Search and Data Mining. 2017：731-739.

[14] YANG C，LIU Z Y，ZHAO D L，et al. Network Representation Learning with Rich Text Information[C]// International Conference on Artificial Intelligence. AAAI Press，2015：2111-2117.

[15] NATARAJAN N，DHILLON I. Inductive matrix completion for predicting gene-disease associations[J]. Bioinformatics，2014，30(12)：60-68.

[16] HOU C P，NIE F P，ZHANG C S，et al. Multiple rank multi-linear SVM for matrix data classification[J]. Pattern Recognition，2014，47(1)：454-469.